

Санкт-Петербургский государственный университет  
Кафедра теории управления

Ларочкин Петр Викторович

Выпускная квалификационная работа

Автоматическая сегментация опухолей головного  
мозга на МРТ-изображениях

Направление 01.03.02

«Прикладная математика, фундаментальная информатика и  
программирование»

Научный руководитель,  
доктор физ.-мат. наук,  
профессор  
Котина Е. Д.

Рецензент,  
кандидат физ.-мат. наук,  
доцент  
Козынченко В. А.

Санкт-Петербург  
2021 г.

# Содержание

<b>Введение</b> . . . . .	3
<b>Постановка задачи</b> . . . . .	5
<b>Обзор литературы</b> . . . . .	7
<b>Глава 1. Датасет</b> . . . . .	8
1.1. Описание датасета . . . . .	8
1.2. Аугментация датасета . . . . .	9
<b>Глава 2. Построение модели для классификации</b> . . . . .	11
2.1. Модели VGG, ResNet и EfficientNet . . . . .	11
2.2. Обучение . . . . .	12
2.3. Оценка эффективности моделей классификации . . . . .	15
<b>Глава 3. Построение модели для сегментации</b> . . . . .	18
3.1. Модели UNET и UNET++ . . . . .	18
3.2. Обучение модели . . . . .	20
<b>Глава 4. Сравнение подходов сегментации</b> . . . . .	21
<b>Выводы</b> . . . . .	24
<b>Заключение</b> . . . . .	25
<b>Список литературы</b> . . . . .	26

## Введение

Магнитно-резонансная томография (МРТ) является одним из ведущих методов для получения анатомо-топографической информации состояния органов человеческого организма. МРТ основан на явлении ядерного магнитного резонанса. Преимущество данного метода в сравнении с другими методами диагностической визуализации – это возможность получения детального изображения мягких тканей, поэтому МРТ широко применяется для визуализации структуры головного мозга, брюшной полости, отделов позвоночника и т.д.

Сегментация МРТ-изображений является необходимой частью обработки исследований и активно развивается в настоящее время. Сегментация – это выделение областей интереса на изображении. Это могут быть задачи выделения долей головного мозга, отдельных позвонков в позвоночнике, а также опухолевых образований в органах [13][14]. Сегментация может проводиться различными методами: нейросетевые методы, методы водораздела, текстурные и другие [14]. Данная проблема является одной из актуальных задач обработки диагностических данных .

В настоящей работе рассматривается автоматическая сегментация опухолевых образований на МРТ-изображениях головного мозга. В связи с все большей автоматизацией процессов обработки МРТ-изображений, данная задача является актуальной, т.к автоматическая обработка позволит облегчить работу медицинских специалистов по обработке МРТ-изображений.

Автоматическая сегментация МРТ-изображений в данной работе производится сверточными нейронными сетями. Сверточные нейронные сети моделируют работу нервных клеток живого организма при распознавании образов. Данный тип нейронных сетей лучше всего подходит для обработки изображений с большим разрешением. Основу нейронных сетей составляет операция свертки, которая применяется последовательно с добавлением нелинейных слоев (функций активации). Таким образом, получается композиция функций или слоев с параметрами, которые можно оптимизировать, чтобы достичь наилучшего результата. Результатом сегментиро-

вания является маска, показывающая, где на оригинальном изображении расположена интересующая область. Конечно, если интересующая область отсутствует на изображении, то возвращается пустая маска, т.е. обычное черное изображение.

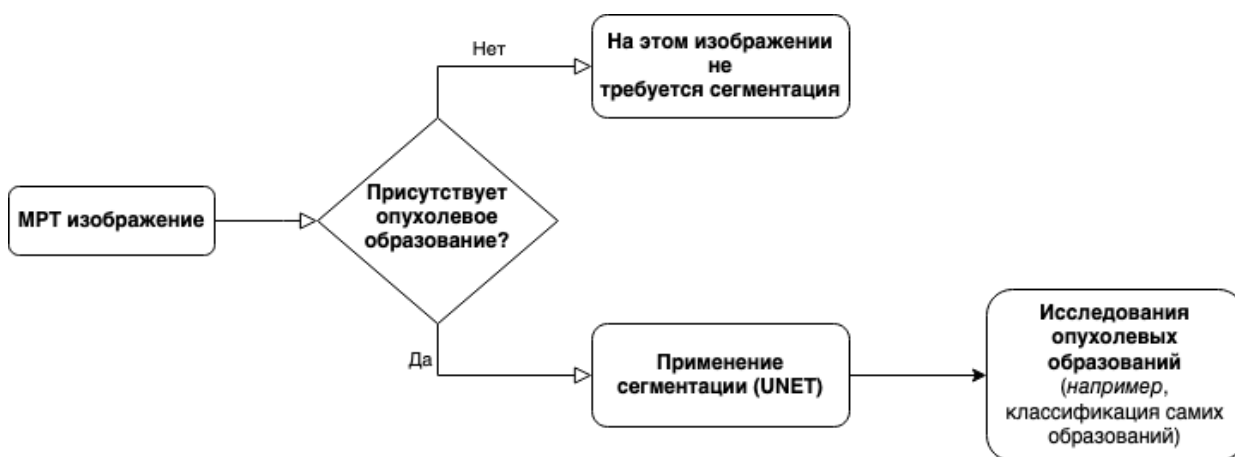
В первой главе описываются используемые данные для построения моделей сегментации изображений, а также для построения моделей классификации изображений. Они представляют собой пары, состоящие из МРТ-изображения и маски нахождения опухоли. Вторая глава посвящена построению модели классификации. Рассматривается ряд архитектур сверточных нейронных сетей для классификации изображений. Исследуются их особенности. Решается задача обучения нейронных сетей для работы по классификации изображений. Производится ROC-анализ этих моделей после обучения для определения наиболее подходящей нейронной сети для решения задачи. Третья глава описывает нейросетевые модели, которые используются для сегментации изображений в данной работе. Описываются особенности модели UNET и ее модификаций. Строится процесс обучения моделей на тренировочных данных. Четвертая глава посвящена сравнению различных подходов к сегментации. Применение моделей классификации и сегментации позволяет построить ряд методов для сегментации образований на МРТ-изображениях. Алгоритм последовательного применения моделей классификации и сегментации может позволить улучшить точность сегментации в сравнении с простым применением нейросети для сегментации.

## Постановка задачи

В данной работе решается задача автоматической сегментации МРТ-изображений с использованием нейронных сетей. Рассматривается два подхода сегментации МРТ-изображений: одноэтапный и двухэтапный. Одноэтапным подходом является использование модели сегментации без первичного применения модели бинарной классификации. Двухэтапным подходом является последовательное применение нейросетевой модели бинарной классификации и модели сегментации. Алгоритм двухэтапного подхода изображен на рис. 1.

Для построения двухэтапного подхода необходимо реализовать модель сегментации и бинарной классификации. Соответственно, МРТ-изображения подразделяются на два класса: МРТ-изображения с опухолевыми образованиями и МРТ-изображения без опухолевых образований. Необходимо оценить работу каждой модели классификации, а также определить наиболее удачную модель для сегментации в одноэтапном и двухэтапном подходах.


Важной задачей является сравнение работы одноэтапного и двухэтапного подходов.



**Рис. 1:** Схема двухэтапной обработки МРТ-изображения

Применение двухэтапного алгоритма имеет смысл, поскольку при использовании сегментатора UNET полученные маски могут показывать опухоль, которой нет на МРТ снимке. А т.к. для определения пустой маски без опухоли достаточно классифицировать изображение отрицательно. Поэто-


му первичное применение модели классификации может стать качественным улучшением точности сегментирования по сравнению с одноэтапным алгоритмом.



**Рис. 2:** МРТ-изображение головного мозга без опухолевого образования



**Рис. 3:** Маска, показывающая отсутствие опухолевого образования



**Рис. 4:** Маска, построенная UNET, показывающая присутствие опухолевого образования

Суммируя вышесказанное, можно выделить основные задачи:

1. Изучить актуальные модели классификации.
2. Построить обучение моделей классификации, оценить качество классификации и выбрать наиболее удачную.
3. Изучить актуальные модели сегментации
4. Обучить модели сегментации, оценить качество работы сегментации.
5. Используя построенные модели, сравнить двухэтапный и одноэтапный подходы.

## Обзор литературы


При решении поставленной задачи был проанализирован широкий круг научной литературы. Основная информация по МРТ и физической основе получения МРТ-изображений были изучены в книге [8]. Актуальные задачи по сегментации МРТ-изображений рассмотрены в статьях [13][14], в частности сегментация МРТ-изображений головного мозга с помощью нейронных сетей рассмотрена в работах [11] [12], проанализирована статьи с методами обработки и сегментации МРТ-изображений [14]. Рассмотрены методы для аугментации МРТ-изображений головного мозга[15][16]. Математическим основам сверточных нейронных сетей и методам оптимизации посвящены следующие работы [10][9]. Особенности работы конкретных нейронных сетей рассмотрены в следующих работах: сверточная нейронная сеть U-NET [1], UNet++ [2], UNET with pretrained encoder[17], EfficientNet [3], ResNet [4], VGG [5]. Тестовые МРТ-изображения для построения моделей были взяты из открытого источника [6].

# Глава 1. Датасет

## 1.1 Описание датасета

Построение нейросетевых моделей классификации и сегментации требует данные для обучения и оценки работы модели. В качестве тренировочного набора данных рассматривается датасет из открытого источника [6]. Датасет содержит информацию о 110 различных исследованиях. Изображения были собраны в режиме FLAIR.

Датасет содержит 3929 RGB изображений головного мозга и масок опухолевых образований. Маски показывают область опухолевого образования на соответствующем ему МРТ-снимке головного мозга. Если же опухоль отсутствует на МРТ-изображении, то маска представляет черное изображение. В текущем датасете рассматриваются опухолевые образования низшей степени злокачественности (LGG). Также помимо указанных изображений присутствует таблица, содержащая информацию о геномных кластерах опухолей.



**Рис. 5:** МРТ-изображение головного мозга с опухолевым образованием




**Рис. 6:** Маска, показывающая область нахождения опухолевого образования

Такой набор данных можно применить для построения модели классификации и сегментации. В данной задаче маска применяется еще и как



индикатор присутствия опухолевого образования для модели классификации. Примеры изображений из датасета приведены на рис. 5, 6, 7, 8.




**Рис. 7:** МРТ-изображение головного мозга без опухолевого образования




**Рис. 8:** Маска, показывающая отсутствие опухолевого образования

## 1.2 Аугментация датасета


В данной работе применяется аугментация данных. Аугментация данных – это расширение тренировочной выборки за счет ее модификации, т.е. построение новых данных, используя текущие. В нашем случае модификацией будет служить одна из двух случайных операций: поворот изображения от -10 до 10 градусов или горизонтальное отзеркаливание. Данные операции для изображений для аугментации при построении моделей классификации типов опухолей применялись в статье[15]. Примеры работы данных операции на рис. 9 - 12.




**Рис. 9:** Оригинальное изображение с наложенной маской из тренировочного набора



**Рис. 10:** Повернутое на случайный угол изображение с наложенной маской



**Рис. 11:** Оригинальное изображение из тренировочного набора с наложенной маской



**Рис. 12:** Случайно отзеркаленное по горизонтали изображение

## Глава 2. Построение модели для классификации

### 2.1 Модели VGG, ResNet и EfficientNet

Первым этапом двухэтапного алгоритма является классификация МРТ-снимков на два класса: снимки с опухолевыми образованиями и снимки без опухолевого образования. В данном пункте рассмотрим модели, которые будут применяться для классификации изображений.

Рассмотрим несколько архитектур сверточных нейронных сетей: VGG16, ResNet-18 и EfficientNet. Данные модели использовались для состязания ImageNet по классификации изображений на 1000 различных классов, в том числе довольно узких классов, поэтому имеет смысл применить данные модели для текущей задачи.

VGG16 является глубокой сверточной сетью с большим количеством сверток и слоев пулинга. Она является одним из лидеров по классификации. К достоинству данной модели можно отнести применение метода DropOut, который помогает бороться с «переобучением» модели. Недостатком этой модели является то, что при увеличении количества слоев функция ошибки при обучении не становится меньше, чем на модели с меньшей глубиной [4]. Архитектура модели VGG16 представлена на рис. 13.

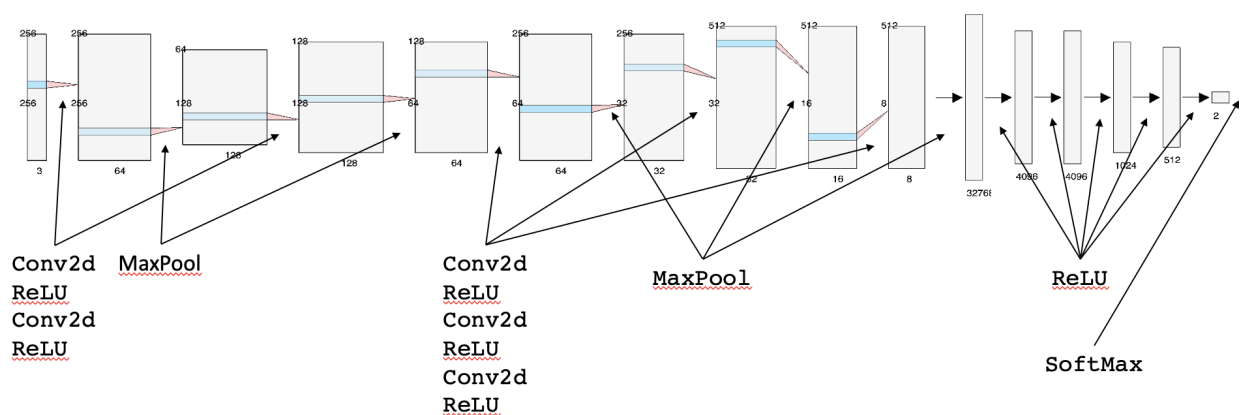



Рис. 13: Архитектура нейронной сети VGG16

У модели ResNet-18 (residual neural network) отсутствует недостаток модели VGG16, за счет применения skip connections. Каждый новый слой лишь «корректирует» результат и не влияет на него полностью. Таким

образом, данный метод при увеличении глубины модели дает меньшую величину ошибки [4]. Архитектура ResNet-18 приведена на рис. 14.



**Рис. 14:** Архитектура нейронной сети ResNet-18

Следующая рассматриваемая нейронная сеть есть EfficientNet. Ее преимуществом в сравнении с моделями VGG и ResNet является меньшее количество параметров при большей точности [3]. Особенность архитектуры заключается в том, что создаются ограничения на количество слоев, разрешение изображения и т.д. Архитектура EfficientNet приведена на рис. 15.



**Рис. 15:** Архитектура нейронной сети EfficientNet

## 2.2 Обучение

В пункте 2.1 были рассмотрены несколько архитектур классификации изображений. Чтобы оценить эффективность той или иной модели, требуется обучить модели при одинаковом тренировочном и валидационном датасете.

Соответственно, прежде чем начать обучать нейронную сеть необходимо определить функцию потерь, т. е. ввести меру качества классификации изображений. Для обучения взята функции потерь бинарная кросс-энтропия (Cross Entropy)

$$l(x, y) = \text{mean}(L) = \text{mean}((l_1, \dots, l_n)),$$

$$l_i(x_i, y_i) = -y_i * \log(x_i) + (1 - y_i) * \log(1 - x_n),$$

где

$n$  – количество снимков, подаваемое для классификации,

$\text{mean}(\cdot)$  – функция, возвращающая среднее значение всего вектора,

$x$  – вектор, предсказанный нейронной сетью,

$y$  – вектор, истинных значений.

Функция активации на последнем слое каждой модели – SoftMax:

$$\text{SoftMax}(x) = (S_1(x_1), \dots, S_n(x_n)),$$

$$S_i(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)}.$$

В данной формуле  $x$  – результат работы последнего слоя, нейронной сети.

Теперь формализуем задачу построения модели. Она заключается в минимизации функции потерь, изменяя конфигурацию весов нейронной сети.

$$\bar{\omega} = \arg \min_{\omega} l(\text{predict}(\omega, \text{input}), \text{target})$$

$$\text{predict} \in (0, 1)$$

$$\text{target} \in \{0, 1\}$$

$\text{predict}$  – результат нейронной сети.

$\text{target}$  – целевой вектор.

$\omega$  – конфигурация весов в нейронной сети.

$\bar{\omega}$  – конфигурация весов, при которой достигается наилучший ре-

зультат.

Задача, описанная выше, есть задача оптимизации, которую можно решить соответствующими методами.

Для этой задачи выбран метод оптимизации *Adam*. Каждая последующая конфигурация весов нейронной сети строится по формуле

$$\omega_{(t+1)} = \omega_{(t)} - \alpha \frac{EMA_{\beta_1}(\nabla f)_{(t)}}{\sqrt{EMA_{\beta_2}(\nabla f^2)_{(t)} + \varepsilon}}.$$

Выбор обусловлен тем, что в нем сосредоточены положительные качества стохастического градиентного спуска и метода *RMSProp*, к тому же это очень распространенный метод оптимизации нейронных сетей.

В этом равенстве операция деления и операция возведения в квадрат поэлементные.

$\omega_{t+1}$  — новые параметры нейронной сети.

$\omega_t$  — старые параметры нейронной сети.

$\alpha$  — скорость обучения (learning rate).

$f$  — функция потерь (loss function).

$\varepsilon$  — константа, предназначенная для исключения случаев деления на ноль.

$EMA(\cdot)$  — это экспоненциальное скользящее среднее, которая вычисляется по следующей формуле

$$EMA_{\beta}(\zeta_t) = (1 - \beta)\zeta_t + \beta EMA_{\beta}(\zeta_{t-1}).$$

$EMA_{\beta}(\zeta_t)$  — значение экспоненциального скользящего среднего на итерации  $t$ .

$\zeta_t$  — значение функции на итерации  $t$ .

Часто используемые значения параметров для большинства задач:


$$\alpha = 3 \cdot 10^{-4}$$

$$\beta_1 = 0.9$$

$$\beta_2 = 0.999$$

В текущей задачи параметр  $\alpha$  был незначительно изменен в процессе ручной настройки гиперпараметров обучения.

После определения основных составляющих для решения задачи обучения модели нейронной сети. Рассмотрим процесс обучения описанных моделей. График метрики (accuracy) на валидационной выборке для каждой эпохи обучения приведен на рис. 16.



**Рис. 16:** График точности (accuracy) на валидационной выборке во время обучения

## 2.3 Оценка эффективности моделей классификации

Оценка работы данных моделей производится с помощью ROC-анализа. Для этого необходимо построить соответствующие ROC-кривые. Рассмотрим всевозможные границы, пороги (threshold) интерпретации результата от 0 до 1 с шагом 0.05. Под границей понимается величина, меньше которой результат идентифицируется как отрицательный и больше которой — как положительный. На оси абсцисс расположены False Positive Rate (FPR), а на оси ординат соответствующему ему True Positive Rate (TPR) с тем же значением границы, порога. Метрики FPR и TPR считаются с помощью матрицы путаницы (confusion matrix). Для каждого порога требуется по-

считать свою матрицу путаницы (confusion matrix). ROC-кривые приведены на рисунке 17.




Рис. 17: ROC-кривые моделей ResNet-18, VGG16, EfficientNet

Confusion matrix	Положительный класс	Негативный класс
Предсказанный положительный	TP	FP
Предсказанный негативный	FN	TN

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

Количественной величиной, показывающей эффективность бинарной классификации, является площадь под ROC-кривой. Ниже представлена таблица с данной метрикой для каждой модели.

Метрика	VGG16	ResNet-18	EfficientNet
площадь под ROC-кривой	0.943808	0.959624	0.91472



Таким образом, среди трех рассмотренных моделей лучше всего показала себя ResNet-18. Она смогла выдать наименьшее количество ошибок первого и второго рода в сравнении с другими нейросетями. Поэтому данная модель будет использоваться для построения двухэтапного алгоритма сегментации.

Пользуясь построенной ROC-кривой можно определить порог разграничения классов 0,1. Такой низкий порог обусловлен тем, что в данной классификации ложноположительные и ложноотрицательные ошибки имеют разную значимость. В данном случае, ложноотрицательные ошибки для классификации более критичны чем ложноположительные ошибки. Таким образом на тестовой выборке была получена следующая матрица путаницы (confusion matrix).

<b>Confusion matrix</b>	Положительный класс	Негативный класс
Предсказанный положительный	135	5
Предсказанный негативный	13	240

$$sensitivity = \frac{TP}{TP + FN}$$

$$specificity = \frac{TN}{TN + FP}$$

Установив необходимый порог, удалось снизить количество ложноотрицательных ошибок. Используя confusion matrix, были подсчитаны специфичность и чувствительность. Специфичность выбранной модели составила 0,97, а чувствительность — 0,91. Базовый алгоритм на основе метода опорных векторов показал 0,87 и 0,58 соответственно.

## Глава 3. Построение модели для сегментации

### 3.1 Модели UNET и UNET++

Вторым этапом двухэтапного алгоритма является сегментация изображений, на которых присутствует опухолевое образование. В данной работе рассматривается популярная модель по сегментации изображения UNET и две ее модификации.

Рассмотрим нейросетевую модель UNET. Она представляет собой набор «сужающих» сверток и «расширяющих» сверток. Также их называют encoder и decoder. Результат «расширяющихся» сверток конкатенируется с результатами соответствующих «сужающих сверток». Похожий метод также применяется в ResNet, для уменьшения потери информации на выходе из каждого слоя нейронной сети. Еще одной интересной особенностью UNET является работа с крайними пикселями. Т.к. крайние пиксели имеют неудачную для операции свертки позицию, информации по ним «собирается» не так много, в отличие от пикселей, которые расположены не с краю. Эта проблема была решена таким образом: вокруг изображения строится рамка из отзеркалированных пикселей, что позволяет лучше обрабатывать изображение. Данная модель хорошо показала себя в задачах сегментации на медико-биологических изображениях [1], однако этим ее спектр приложений не ограничивается. Архитектура UNET представлена на рис. 18.

Рассмотрим также улучшенную модель UNET++. Ее модификация заключается в том, что добавлены еще большее количество всевозможных skip connections и сверток между «сужающими» и «расширяющими» свертками. Такой подход позволил улучшить значение ошибки и точность [2]. Архитектура UNET++ представлена на рис. 19.

Следующим этапом развития применения UNET и UNET++ можно считать использования предобученного encoder. Т.к. encoder представляет собой обычную сверточную нейронную сеть, например, для классификации, в UNET-модели можно использовать предобученные на распознавание изображений нейронные сети, например уже знакомую ResNet-18. Данный подход позволяет ускорить обучение модели, так как чаще всего веса

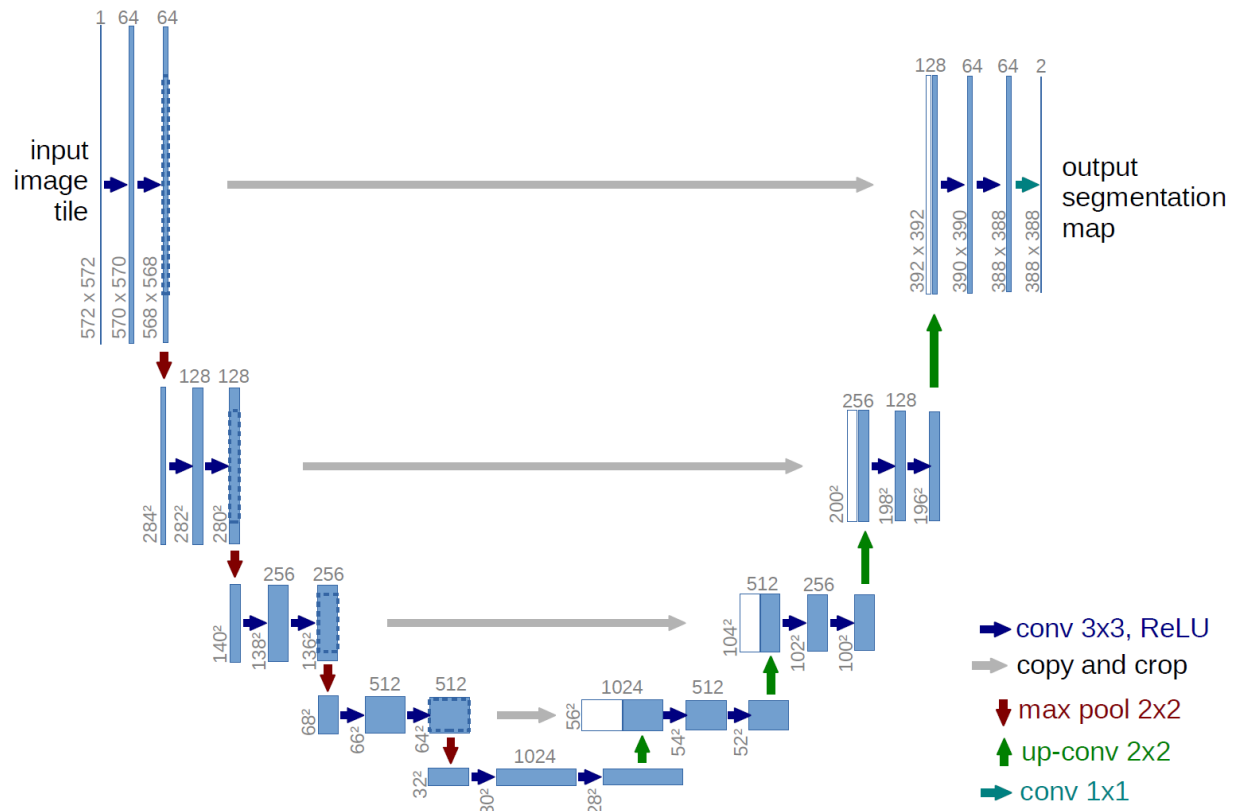


Рис. 18: Архитектура UNET




Рис. 19: Архитектура UNET++

очень похожи для первых слоев сверточных нейросетей для распознавания изображений. Похожий подход использования предобученных первых слоев нейросети применятся и для обычных сверточных сетей, он называется *transfer learning*.

## 3.2 Обучение модели

Рассматривается та же задача обучения, что и в пункте 2.2. Однако в задачах сегментации применяется функция потерь, построенная с помощью коэффициента Дайса:

$$DC = \frac{2|X \cap Y|}{|X| + |Y|},$$

$$diceLoss(predict, target) = 1 - diceCoefficient(predict, target).$$

$$\bar{\omega} = \arg \min_{\omega} diceLoss(predict(\omega, input), target).$$

$\bar{\omega}$  — конфигурация весов, при которой достигается наилучший результат.

Для сравнения двухэтапного и одноэтапного алгоритма требуются модели сегментации, которые обучены сегментировать изображения обоих классов. Для одноэтапного подхода это необходимо, потому что изображения именно этих классов будут сегментироваться. Обучать модели сегментации для двухэтапного подхода можно используя только изображения положительного класса, однако обучение нейросети на изображениях обоих классов позволит сократить число возможных ошибок, т.к. при построении модели классификации порог интерпертации результата определен низко, то может увеличиться число ложноположительных результатов при уменьшении более значимых ложноотрицательных. Модель обученная на двух классах сможет дополнительно «проверять» изображение, позволив «исправить» результат.

## Глава 4. Сравнение подходов сегментации

Таким образом, используя классификатор, можно построить двухэтапный подход к сегментации МРТ-изображения, где первый этап — бинарная классификация МРТ-изображения, а второй этап — сегментация МРТ-изображения с опухолевым образованием. Одноэтапным подходом будем считать применение сегментатора для МРТ-изображения без первичного классифицирования. В этой главе рассмотрим несколько вариантов двухэтапного и одноэтапного подходов. Для двухэтапного подхода будет использоваться нейронная сеть ResNet-18. Для одноэтапного будет использоваться несколько модификаций моделей UNET.

Для оценки двух подходов сегментации воспользуемся *Dice coefficient*. Эта метрика показывает меру сходства двух масок, областей на изображении. Для идентичных одноканальных изображений ее значение составляет 1, для абсолютно разных, например для черного и белого изображений — 0.

Работа каждого подхода оценивается с помощью среднего значения коэффициента Дайса, набранного на тестовой выборке. Также нужно учесть то, что классы в тестовой выборке не сбалансированы, поэтому имеет смысл сбалансировать классы, чтобы лучше оценить вклад классификации в алгоритм, т.к. среднее значение метрики очень чувствительно к несбалансированным классам при классифицировании. Наиболее интересен результат сравнения двухэтапного алгоритма, где первый этап применения есть ResNet-18, а второй — применение UNET, и одноэтапного алгоритма, где моделью сегментации является модель UNET с предобученным encoder, ResNet-18, т.к. эти подходы очень схожи.

Результаты работы каждого алгоритма представлены на таблице ниже.

Алгоритм сегментации	Средний коэффициент Дайса
ResNet-18 and UNET with enc	0.92044
UNET with enc	0.81321
ResNet-18 and UNET++	0.90855
UNET++	0.74600
ResNet-18 and UNET	0.88828
UNET	0.70387

ResNet-18 and UNET with enc – двухэтапный алгоритм, сегментатор UNET с encoder Resnet-18.

UNET with enc – одноэтапный алгоритм, сегментатор UNET с encoder Resnet-18.

ResNet-18 and UNET++ – двухэтапный алгоритм, сегментатор UNET++.


UNET++ – одноэтапный алгоритм, сегментатор UNET++.

ResNet-18 and UNET – двухэтапный алгоритм, сегментатор UNET.


UNET – одноэтапный подход, сегментатор UNET.

Были получены следующие результаты. По данной метрике лучшим показал себя двухэтапный алгоритм с моделью UNET with encoder.


Стоит отметить, что введение дополнительного этапа обработки во всех случаях повысило средний коэффициент Дайса в сравнении с соответствующим одноэтапным алгоритмом. Недостатком такого алгоритма является то, что необходимо последовательно обучать две модели вместо одной. Примеры работы двухэтапного алгоритма изображены на рис. 21-29.




**Рис. 20:** МРТ-изображение головного мозга с опухолевым образованием




**Рис. 21:** Истинная маска, показывающая область нахождения опухолевого образования




**Рис. 22:** Предсказанная маска, показывающая область нахождения опухолевого образования




**Рис. 23:** МРТ-изображение головного мозга с опухолевым образованием




**Рис. 24:** Истинная маска, показывающая область нахождения опухолевого образования




**Рис. 25:** Предсказанная маска, показывающая область нахождения опухолевого образования



**Рис. 26:** МРТ-изображение головного мозга без опухолевого образования



**Рис. 27:** Истинная маска, показывающая отсутствие опухолевого образования



**Рис. 28:** Предсказанная маска, показывающая отсутствие опухолевого образования

## Выводы

В данной работе была рассмотрена задача автоматической сегментации опухолей головного мозга на МРТ-изображениях. Был рассмотрен двухэтапный алгоритм автоматической сегментации. Построение такого алгоритма имеет свои тонкости для удачного взаимодействия двух моделей. Во-первых, используя классификатор для первичной обработки в двухэтапном алгоритме, необходим учет не только ложноположительных ошибок, но и ложноотрицательных. В двухэтапном подходе уменьшение ложноотрицательных ошибок выполнено за счет низкого порога интерпретации результата в модели классификации, уменьшение ложноположительных же ошибок – за счет совместной обработки изображения моделями классификации и сегментации. Во-вторых, необходимо решить технические вопросы реализации обучения моделей, т.к. изображений в тренировочном наборе данных с учетом аугментации довольно много и сами изображения преобразуются в трехмерные матрицы с типом `float`, то загрузка данных в оперативную память может переполнять ее, поэтому был реализован подход загрузки изображений из ПЗУ во время обучения моделей. В-третьих, тонкостью является оценка подходов сегментации. В тестовой выборке как и в тренировочной присутствует несбалансированность классов, что в свою очередь влияет на средний коэффициент Дайса на тестовой выборке, поэтому для сравнения алгоритмов, определения вклада классификации в двухэтапный подход необходимо сбалансировать классы.

Продолжением данной работы может быть:

- Построение единой модели, которая бы собрала наилучшие качества двух подходов.
- Использование ансамблей алгоритмов на этапе классификации в двухэтапном подходе (бэггинг и бустинг).



## **Заключение**

В ходе работы были выполнены все поставленные задачи. Рассмотрены архитектуры для классификации изображений. Реализованы нейросетевые модели классификатора для первичной обработки МРТ-изображений и была произведена оценка их работы, выбрана наиболее удачная. Исследованы особенности архитектур UNET и ее модификаций. Данные модели были обучены на рассмотренном датасете. Используя модели сегментации и модель бинарной классификации, удалось построить двухэтапный подход сегментации МРТ-изображений. Были построены сравнительные оценки двухэтапного и одноэтапного подходов с применением оригинальной модели UNET и ее усовершенствований.

### **Основные результаты работы:**

- 1. Построен одноэтапный алгоритм автоматической сегментации МРТ изображений.**
- 2. Построен двухэтапный алгоритм автоматической сегментации с использованием классификатора.**
- 3. Проведен анализ и сравнение разработанных алгоритмов.**

Построенные алгоритмы могут быть полезны в обработке МРТ-изображений при визуализации и исследовании опухолевых образований головного мозга.

## Список литературы

- [1] Ronneberger O. U-Net: Convolutional Networks for Biomedical Image Segmentation / O. Ronneberger, P. Fischer , T. Brox // Medical Image Computing and Computer-Assisted Intervention (MICCAI). — 2015. — C.234-241.
- [2] A Nested U-Net Architecture for Medical Image Segmentation. In: Stoyanov D. et al. (eds) Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. DLMIA 2018, ML-CDS 2018. Lecture Notes in Computer Science, vol 11045. / Z. Zhou [et al.] // Springer, Cham. — 2018.
- [3] Tan M. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks / M. Tan, Q. V. Le // CoRR. — 2019.
- [4] He K. Deep Residual Learning for Image Recognition / K. He, X. Zhang, R. Shaoqing, J. Sun // CoRR. — 2015.
- [5] Simonyan K. Very Deep Convolutional Networks for Large-Scale Image Recognition / K. Simonyan, A. Zisserman // CoRR. — 2014.
- [6] Kaggle [Электронный ресурс]: URL: <https://www.kaggle.com/mateuszbeda/lgg-mri-segmentation> (дата обращения: 15.05.2021).
- [7] Pytorch [Электронный ресурс]: URL: <https://pytorch.org/docs/stable/index.html> (дата обращения: 15.05.2021).
- [8] Марусина, М.Я. Современные виды томографии / М.Я. Марусина, А.О. Казначеева. — Санкт-Петербург: СПбГУ ИТМО, 2006. — 132с.
- [9] Аббасов М.Э. Методы оптимизации / М.Э. Аббасов. — СПб: ВВМ, 2014. — 64 с.
- [10] Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу. — Москва: ДМК Пресс, 2018. — 652 с.

- [11] Segmenting brain tumors from FLAIR MRI using fully convolutional neural networks / [P. Lorenzo, J. Nalepa, B. Bobek-Billewicz та ін.] // Computer Methods and Programs in Biomedicine. — 2019. — № 176. — C.135-148.
- [12] Işın A. Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods / A. Işın, C. Direkoğlu, M. Şah // Procedia Computer Science. — 2016. — № 102. — C.317-324.
- [13] Despotović, I. MRI Segmentation of the Human Brain: Challenges, Methods, and Applications [Electronic resource] / I. Despotović, B. Goossens, W. Philips // Computational and Mathematical Methods in Medicine. — 2015. — Vol. 2015. — Available from: <https://doi.org/10.1155/2015/450341>.
- [14] MRI segmentation: Methods and applications / [L. Clarke, R. Velthuisen, M. Camacho та ін.] // Magnetic Resonance Imaging. — 1995. — № 3. — C.343-368.
- [15] Nalepa J. Data Augmentation for Brain-Tumor Segmentation: A Review / J. Nalepa, M. Direkoğlu, M. Kawulok // Frontiers in Computational Neuroscience. — 2019. — № 13. — C.83.
- [16] Ning X. Image Classification of Brain Tumors Using Improved CNN Framework with Data Augmentation / X. Ning, Z. Li, H. Pang // Mobile Computing, Applications, and Services. - 2020. - C.83-101
- [17] Iglovikov V. TerausNet: U-Net with VGG11 Encoder Pre-Trained on ImageNet for Image Segmentation / V. Iglovikov, A. Shvets// CoRR. - 2018.